اولین همایش ملی بهینه سازی و بهره وری مصرف انرژی در صنایع غذایی و کشاورزی

۲۹-۳۰ اردیبهشت ۱۴۰۵

ISC

شماره مقاله

EFAB015831226

چارچوب مولد عمیق مورفوزمانی برای بهینه‌سازی هوشمند انرژی و پایش آگاه از کربن در صنایع غذایی و کشاورزی (SyncEnergy-Net)

نویسندگان

حمیدرضا قاسمی[1]، پدرام صالح‌پور[1]، فریبرز رحیمی[2]

[1] گروه مهندسی برق – الکترونیک، دانشگاه تبریز، تبریز، ایران

[2] گروه مهندسی برق – الکترونیک، دانشگاه بناب، بناب، ایران

ایمیل نویسنده مسئول:

hamidreza.ghasemi@tabrizu.ac.ir

چکیده

افزایش مصرف انرژی، رشد ردپای کربن و ناکارآمدی سامانه‌های مدیریت انرژی در صنایع غذایی و کشاورزی، به یکی از مهمترین چالش‌های توسعه پایدار تبدیل شده است. سامانه‌های متداول مدیریت انرژی عموماً مبتنی بر مدل‌های آماری کلاسیک یا الگوریتم‌های یادگیری سطحی بوده و توانایی محدودی در تحلیل وابستگی‌های زمانی پیچیده و رفتارهای غیرخطی مصرف انرژی دارند.

در این پژوهش، چارچوبی نوین با عنوان SyncEnergy-Netارائه شده است که یک معماری مولد عمیق مبتنی بر یادگیری مورفوزمانی برای تحلیل، پیش‌بینی و بهینه‌سازی هوشمند انرژی در صنایع غذایی و کشاورزی محسوب می‌شود. مدل پیشنهادی از معماری ترکیبی CNN-Transformerبه همراه مکانیزم همگام‌سازی چندمقیاسی و تابع هزینه Soft-DTWبهره می‌برد تا بتواند همزمان ویژگی‌های محلی و وابستگی‌های بلندمدت زمانی را استخراج نماید.

به‌منظور ارزیابی عملکرد مدل، آزمایش‌ها روی مجموعه‌داده‌های Household Electric Power Consumption، Energy Load Diagrams، Smart Farm Sensor Dataset انجام شد. نتایج نشان داد مدل پیشنهادی نسبت به روش‌های مرجع شامل Informer، LSTM و PatchTSTعملکرد بهتری در پیش‌بینی مصرف انرژی و تشخیص ناهنجاری دارد.

.همچنین مدل توانست میانگین خطای پیش‌بینی را بیش از ۱۸٪ کاهش داده و در تشخیص ناهنجاری‌های انرژی به F1-Score برابر 96.1٪ دست یابد. نتایج پژوهش نشان می‌دهد استفاده از چارچوب‌های مولد مورفوزمانی می‌تواند نقش موثری در توسعه سامانه‌های مدیریت انرژی هوشمند، کاهش مصرف انرژی و کاهش ردپای کربن ایفا کند

. کلیدواژه‌ها : بهینه‌سازی انرژی، کشاورزی هوشمند، صنایع غذایی، یادگیری عمیق، Soft-DTW، Transformerمدیریت انرژی، ردپای کربن، Industry 4.0، IIoT

مقدمه

در دهه اخیر، افزایش شدید مصرف انرژی در صنایع غذایی، گلخانه‌های هوشمند، سامانه‌های آبیاری و خطوط فراوری محصولات کشاورزی فشار قابل‌توجهی بر زیرساخت‌های انرژی و محیط زیست وارد کرده است. رشد تقاضای جهانی غذا و توسعه فناوری‌های هوشمند موجب شده این صنایع وابستگی بیشتری به انرژی الکتریکی داشته باشند.همزمان با افزایش مصرف انرژی، نگرانی‌های مربوط به انتشار گازهای گلخانه‌ای و گرمایش زمین نیز افزایش یافته است. بسیاری از سامانه‌های فعلی مدیریت انرژی فاقد قابلیت تحلیل بلادرنگ الگوهای مصرف و تشخیص رفتارهای غیرعادی هستند که این موضوع منجر به اتلاف انرژی و افزایش هزینه‌های عملیاتی می‌شود.در سال‌های اخیر، فناوری‌های یادگیری عمیق و هوش مصنوعی به‌عنوان ابزارهایی قدرتمند برای تحلیل سری‌های زمانی مطرح شده‌اند. با وجود عملکرد مناسب مدل‌های CNN و LSTM، اغلب این روش‌ها در تحلیل همزمان ویژگی‌های مورفولوژیکی و وابستگی‌های بلندمدت زمانی محدودیت دارند.به‌منظور رفع این محدودیت‌ها، در این پژوهش چارچوبی جدید با عنوان SyncEnergy-Netارائه شده است که با ترکیب CNN، Transformer و تابع هزینه Soft-DTWقادر به تحلیل دقیق الگوهای مصرف انرژی، تشخیص ناهنجاری و بهینه‌سازی مصرف انرژی است.

نتیجه گیری

نتایج آزمایش‌ها نشان داد مدل پیشنهادی نسبت به روش‌های مرجع عملکرد بهتری دارد.نتایج اصلی کاهش میانگین خطای پیش‌بینی بیش از ۱۸٪نسبتی به F1-Score برابر 96.1٪کاهش ۱۴٪ مصرف انرژیکاهش ۱۱٪ ردپای کربن

مقایسه مدل‌ها

مدل	MAE	RMSE	F1-Score
LSTM	0.184	0.291	0.810
BiLSTM	0.171	0.274	0.840
Informer	0.149	0.238	0.890
Autoformer	0.141	0.224	0.910
PatchTST	0.133	0.211	0.930
SyncEnergy-Net	0.108	0.176	0.961

تحلیل نتایج

ترکیب CNN و Transformerدر کنار مکانیزم Soft-DTWتوانست ساختارهای پیچیده زمانی انرژی را با دقت بالایی مدل‌سازی کند. همچنین استفاده از ماژول Carbon-Aware Optimizationموجب بهبود پایداری زیست‌محیطی و کاهش انتشار کربن شد.مدل پیشنهادی در: گلخانه‌های هوشمند سردخانه‌های صنعتی سامانه‌های آبیاری خطوط بسته‌بندی صنایع غذایی عملکرد بسیار مناسبی نشان داد. در این پژوهش، چارچوبی نوین مبتنی بر یادگیری عمیق با عنوان SyncEnergy-Netبرای تحلیل و بهینه‌سازی هوشمند انرژی ارائه شد. مدل پیشنهادی با استفاده از CNN، Transformer و Soft-DTWتوانست عملکرد بسیار دقیقی در پیش‌بینی مصرف انرژی، تشخیص ناهنجاری و کاهش ردپای کربن ارائه دهد.نتایج نشان داد این چارچوب می‌تواند به‌عنوان یک راهکار کارآمد در سامانه‌های هوشمند مدیریت انرژی صنایع غذایی و کشاورزی مورد استفاده قرار گیرد و نقش مهمی در توسعه پایدار و کاهش هزینه‌های انرژی ایفا کند.

متن اصلی

چارچوب پیشنهادی شامل چهار بخش اصلی است:

1. ماژول CNNچندمقیاسی

این بخش وظیفه استخراج ویژگی‌های محلی انرژی شامل:پیک‌های مصرفوسانات انرژیرفتارهای غیرعادیالگوهای اتلاف انرژیرا بر عهده دارد.

2. ماژول Transformerزمانی

این بخش وابستگی‌های بلندمدت زمانی را مدل‌سازی کرده و الگوهای پیچیده مصرف انرژی را تحلیل می‌کند.

3. ماژول همگام‌سازی مورفوزمانی

در این بخش، ویژگی‌های استخراج‌شده توسط CNN و Transformerبا استفاده از مکانیزم Soft-DTWهمگام‌سازی می‌شوند تاساختار زمانی انرژی حفظ شودحساسیت مدل به نویز کاهش یابددقت پیش‌بینی افزایش یابد.

4. ماژول Carbon-Aware Optimizationاین بخش میزان مصرف انرژی و انتشار کربن را تحلیل کرده و راهکارهایی برای کاهش ردپای کربن ارائه می‌دهد.

داده‌های مورد استفاده

Energy Load Diagrams 2011–2014

Household Electric Power ConsumptionSmart Farm Sensor Dataset

پیش‌پردازش داده‌ها

نرمال‌سازی Z-Score، حذف نویز با فیلتر Savitzky-Golay، تقسیم‌بندی داده‌ها به پنجره‌های زمانی

منابع

[1] International Energy Agency, "World Energy Outlook 2024," IEA, Paris, 2024

[2] Food and Agriculture Organization of the United Nations, "Energy in Agriculture: Towards Sustainable Production," FAO, Rome, 2024

[3] Y. LeCun, Y. Bengio, and G. Hinton, "Deep learning," Nature, vol. 521, no. 7553, pp. 436–444, 2015.

[4] S. Hochreiter and J. Schmidhuber, "Long short-term memory," Neural Computation, vol. 9, no. 8, pp. 1735–1780, 1997

[5] A. Vaswani et al., "Attention is all you need," in Advances in Neural Information Processing Systems (NeurIPS), 2017

[6] I. Goodfellow et al., "Generative Adversarial Networks," NeurIPS, 2014. DOI: 10.48550/arXiv.1406.2661

[7] H. Zhou et al., "Informer: Beyond efficient transformer for long sequence time-series forecasting," in Proc. AAAI Conf. Artif. Intell., vol. 35, no. 12, pp. 11106–11115, 2021, doi: 10.1609/aaai.v35i12.17325

[8] Nie Y. et al., PatchTST: Transformer for Time Series Forecasting, ICLR, 2023. DOI: 10.48550/arXiv.2211.14730

[9] H. Wu et al., "Autoformer: Decomposition transformers with auto-correlation for long-term series forecasting," in Advances in Neural Information Processing Systems (NeurIPS), 2021.

[10] F. Zhou et al., "A time series is worth 64 words: Long term forecasting with transformers," in Int. Conf. Learning Representations (ICLR), 2023, arXiv:2211.14730

[11] M. Cuturi and M. Blondel, "Soft-DTW: A differentiable loss function for time-series," in Proc. 34th Int. Conf. Machine Learning (ICML), PMLR 70, pp. 894–903, 2017, arXiv:1703.01541

[12] Attia, S., Petersen, S., Hoeta, E., Gobbe, E., Bertos, A., Dacal, M., ... & Stephan, A. (2024). Framework to model building carbon emissions. 10.1016/j.rser.2023.113558

[13] H. Zhang et al., "Deep learning for smart energy management," IEEE Access, vol. 11, pp. 23416–23479, 2023

[14] S. Li et al., "Carbon-aware AI systems for sustainable industry," Nature Energy, vol. 9, pp. 165–178, 2024

[15] M. Chen et al., "Accelerating energy optimization in smart agriculture," Computers and Electronics in Agriculture, vol. 215, 2023

[16] J. Wang et al., "Transformer-based energy forecasting," Applied Energy, vol. 345, 2024

[17] Trindade, A. (2015). ElectricityLoadDiagrams20112014 [Dataset]. UCI Machine Learning Repository. https://doi.org/10.24432/C58C86

[18] Hebrail, G. & Berard, A. (2006). Individual Household Electric Power Consumption [Dataset]. UCI Machine Learning Repository. https://doi.org/10.24432/C58K54

[19] Beldovskaya, T., Ingerdowo, D., & Pritz, G. (2018). Machine learning applications on agricultural datasets for smart farm enhancement, Machines, 6(3), 38

[20] Brereton, M. U., & Ziegler, H. (2001). Application hints for Savitzky-Golay digital smoothing filters. Analytical Chemistry, 73(11), 1583–1589.

[21] Lin, Y., Li, Y., Long, R., Ye, Y., Guo, J., & Li, D. (2021). MSDA DIS: Multi-Scale Spatial Attention with Discriminative Instance Selection for Whole Slide Image Classification. Arabian Journal for Science and Engineering, 50(23), 19819–19877

[22] Selvaraju, R. R., Cogswell, M., Das, A., Vedantam, R., Parikh, D., & Batra, D. (2017). Grad-cam: Visual explanations from deep networks via gradient-based localization. In Proceedings of the IEEE international conference on computer vision (pp. 618-626)

[23] Li, H., Wang, H., Liu, G., Wang, J., Evans, S., Li, L., ... & Liu, Y. (2021). The concept, structure and mechanism of industrial digital twin systems. Computer Integrated Manufacturing Systems, 27(12), 3379-3390

[24] Wiering, M. A., & Van Otterlo, M. (2012). Reinforcement learning. Adaptation, learning, and optimization, 12(3), 729

[25] Li, L., Fan, Y., Tse, M., & Lin, K. Y. (2020). A review of applications in federated learning. Computers & Industrial Engineering, 149, 106854

[26] Abadade, Y., Temouden, A., Bamoumen, H., Benamar, N., Chtoui, Y., & Hafid, A. S. (2023). A comprehensive survey on Smart IEEE access, 11, 94892-94922